

UNIVERSIDADE DO VALE DO RIO DOS SINOS — UNISINOS
UNIDADE ACADÊMICA DE GRADUAÇÃO
CURSO DE ENGENHARIA ELÉTRICA

MATUSALLAN CORRÊA DA SILVA

SISTEMA DE MITIGAÇÃO DE COLISÕES POR MEIO DE VISÃO COMPUTACIONAL:
DETECÇÃO DE APROXIMAÇÃO DE VEÍCULOS

SÃO LEOPOLDO-RS
2021

MATUSALLAN CORRÊA DA SILVA

SISTEMA DE MITIGAÇÃO DE COLISÕES POR MEIO DE VISÃO COMPUTACIONAL:
DETECÇÃO DE APROXIMAÇÃO DE VEÍCULOS

Trabalho de Conclusão de Curso apresentado
como requisito para obtenção do título de
Bacharel em Engenharia Elétrica, pelo Curso
de graduação da Universidade do Vale do Rio
dos Sinos - UNISINOS

Orientador:
Prof. Dr. Rodrigo Marques Figueiredo

São Leopoldo-RS
2021

Aos meus pais.

*If I have seen further,
it is by standing upon the shoulders of giants.*

— SIR ISAAC NEWTON

AGRADECIMENTOS

Este trabalho representa a conclusão de uma etapa muito importante de minha vida. Foram muito anos de dedicação para finalmente chegar a este ponto. É com muita alegria e satisfação que escrevo estas palavras para agradecer a todos que contribuíram de alguma forma para este momento. Obviamente tive muitos méritos e dediquei muito tempo e suor não só ao desenvolvimento deste trabalho de conclusão, mas de todo curso de engenharia elétrica. Entretanto, devo a todos os professores e ao meu orientador um muito obrigado pelos ensinamentos. Além disso, não poderia deixar de fazer um agradecimento especial a três pessoas muito importantes que tiveram participação direta em todo este processo, os meus pais Ronivaldo Corrêa da Silva e Juliana Hannecker da Silva e minha esposa Valéria Mareth por todo incentivo, carinho e paciência. Não tenho dúvidas que seria muito mais difícil concluir este curso sem o apoio de vocês.

RESUMO

A evolução da tecnologia tem permitido enormes evoluções na sociedade em geral, um dos ramos que vem se destacando é o setor automobilístico. Diversos sistemas para aumento de conforto e principalmente da segurança dos condutores tem sido desenvolvidos, sendo o alvo deste trabalho sistemas de auxílio de direção que se destinam a utilização de visão computacional para sinalizar a aproximação de veículos. A aplicação proposta recebe imagens de uma câmera ou de uma base de dados e analisando estas imagens consegue reconhecer as linhas divisórias de uma rodovia e identificar veículos. A partir das linhas da rodovia criou-se correções de rota para manter o veículo no centro da pista, além disso, este sistema foi capaz de medir a distância entre outros veículos localizados a sua frente e para cada objeto detectado na imagem marca com uma caixa delimitadora que altera sua coloração conforme distância e posição deste objeto na pista de rodagem. O objetivo deste estudo foi desenvolver um sistema de visão computacional para sinalização de aproximação de veículos para mitigar colisões. Capaz de reconhecer linhas de uma rodovia através de imagens e indicar correções de direção necessárias para manter-se no centro da pista. O sistema em questão usa apenas imagens, um conjunto de algoritmos e cálculos aritméticos para tomada de decisão, ou seja, não possui contribuição de sensores físicos. Para o reconhecimento das linhas de referência da pista foi feito um pré-processamento da imagem e aplicado o algoritmo de detecção de bordas Canny em conjunto com a transformada de Hough. A identificação de objetos foi realizada com a rede neural *You Only Look Once* (YOLO) e para estimativa de distâncias fez-se uso de conceitos de distância focal. Todos demais processos foram resolvidos via cálculos aritméticos. Com esta abordagem atingiu-se bons resultados na detecção de objetos, identificação de linhas da rodovia e cálculo de distancia de veículo mesmo em condições climáticas desfavoráveis como à noite e com chuva. Para casos de chuva intensa obteve-se maiores dificuldades devido a distorções da imagem causados pelo excesso de água. A aplicação é viável e funcional, pois atinge de forma satisfatória a todos objetivos propostos, atingindo um erro médio de 8% para o cálculo de distâncias entre veículos.

Palavras-chave: Veículo autônomo. Visão computacional. Detecção veicular.

LISTA DE FIGURAS

1	Diagrama de blocos	27
2	Trajetos realizados para aquisição de dados	28
a	São Leopoldo para São Leopoldo	28
b	São Leopoldo para Novo Hamburgo	28
c	Canoas para São Leopoldo	28
d	São Leopoldo para Canoas	28
3	Infográfico do projeto	33
4	Fluxo de testes / validação	34
5	Filtro Blur	37
6	Detector de bordas Canny	38
7	Regão de interesse	39
8	Detecção de linhas	40
9	Sobreposição das linhas detectadas	41
10	Teste durante a noite e com chuva leve	41
11	Teste durante a noite e com chuva intensa	42
12	Detecção de objetos	43
13	Detecção de objetos durante noite e chuva leve	43
14	Detecção de objetos durante noite e chuva intensa	44
15	Estimativa de distâncias e variação de cor da caixa delimitadora	46
16	Estimativa de distâncias para objetos à mais de 22 metros	46
17	Aplicação completa	47
18	QR Code - Vídeos demonstrativos	48

LISTA DE TABELAS

1	Sinalização horizontal	18
2	Artigos correlatos	25
3	Informações técnicas da câmera	35
4	Informações técnicas do notebook	36
5	Estimativa de distâncias	45

SUMÁRIO

1	INTRODUÇÃO	8
2	REFERENCIAL TEÓRICO	11
2.1	CONCEITOS BÁSICOS	11
2.1.1	Visão computacional	11
2.1.2	Veículos autônomos	12
2.1.3	Processamento de imagem	14
2.1.4	Sistema de marcação de rodovias no Brasil	16
2.2	TRABALHOS CORRELATOS	18
3	METODOLOGIA	27
4	ANÁLISE E RESULTADOS	37
4.1	Pré-processamento	37
4.2	Identificação de linhas	39
4.3	Deteção de objetos	42
4.4	Estimativa de distâncias	44
4.5	Resultado final	47
5	CONCLUSÃO	49
	REFERÊNCIAS	51

1 INTRODUÇÃO

O rápido avanço da tecnologia trouxe uma série de novas possibilidades de melhorias e desenvolvimentos. No setor automotivo não poderia ser diferente, e atualmente os olhos estão voltados para possibilidade de construir veículos totalmente autônomos, ou seja, veículos não tripulados capazes de auto guiar-se de forma segura e eficiente utilizando sensores para obter informações do ambiente. Esta novidade que até poucos anos atrás parecia apenas ficção científica já está em uso principalmente em países mais desenvolvidos em aplicações específicas. Apesar dos grandes investimentos por parte de empresas, a complexidade desta tarefa ainda exige diversos estudos em busca de melhorias, para só assim alcançar os níveis mais populares da sociedade.

Esse grau de automação veicular pode trazer ótimas contribuições sociais, como redução de acidentes, visto que o erro humano é causa de grande parte deles, redução de congestionamentos, aumento da capacidade das rodovias e aprimoramento do transporte público são outras melhorias que podem ser alcançadas ao se imaginar um sistema de gerenciamento central, capaz de analisar as informações disponibilizadas por estes automóveis. Além disso, esse novo conceito tem potencial para reduzir a emissão de gases e consumo dos veículos, pois seria possível criar modelos otimizados de condução e generalizá-los. Contribuindo com as pesquisas de veículos autônomos, especialmente estudos em português que ainda são escassos, este trabalho tem como objetivo principal:

- Desenvolver um sistema de visão computacional para sinalização de aproximação de veículos para mitigar colisões.

Como objetivos específicos espera-se:

- Reconhecer linhas de uma rodovia através de imagens;
- Indicar correções de direção necessárias para manter-se no centro da pista;
- Localizar veículos envolvidos no trânsito;
- Estimar distância dos veículos localizados na mesma pista de rodagem que o usuário.

Para atingir os objetivos propostos será desenvolvido uma aplicação que recebe imagens de uma câmera ou mesmo de uma base de dados e através da análise destes dados possa reconhecer as linhas divisórias de uma rodovia, identificar veículos e pessoas. Estes objetos identificados devem ser marcados com uma caixa delimitadora na imagem original de forma

que o usuário consiga verificar o que a máquina está percebendo do ambiente. Pretende-se que a partir das informações abstraídas da imagem a aplicação sugira correções de rota para que o veículo se mantenha no centro da pista.

Além disso, o sistema deve ser capaz de estimar a distância do veículo identificado na mesma pista de rodagem, marcando a caixa delimitadora do objeto com cores diferentes dependendo da distância percebida.

Após esta introdução o trabalho está dividido em 4 outros capítulos, sendo eles referencial teórico, metodologia, análise e resultados, conclusão, além das referências. O capítulo de referencial teórico é particionado em conceitos básicos, que explana de forma breve sobre os principais temas que permeiam este projeto. E o subcapítulo de trabalhos correlatos, que descreve a pesquisa realizada entre diversos autores em busca de conhecimento prévio sobre o assunto, e entender o panorama atual das tecnologias utilizadas na resolução de problemas que envolvem veículos autônomos. O capítulo de metodologia contém de forma detalhada as propostas de projeto para atingir os objetivos. O capítulo de análise e resultados apresenta e descreve as respostas do sistema aos diversos testes de validação realizados durante a execução do trabalho. Finalizando com um capítulo de conclusão que contém uma síntese de tudo que foi abordado e propõem novas contribuições que seriam interessantes para trabalhos futuros.

2 REFERENCIAL TEÓRICO

Nesta seção apresentam-se alguns tópicos relevantes para melhor compreensão dos principais assuntos abordados nesta monografia. Este capítulo está dividido em dois principais itens, conceitos básicos e trabalhos correlatos. Contendo na etapa de conceitos básicos uma introdução aos principais temas que envolvem o estudo. E na etapa de trabalhos correlatos são discutidos métodos empregados por alguns pesquisadores para resolver problemas envolvendo visão computacional e detecção de faixas e objetos.

2.1 CONCEITOS BÁSICOS

Para conceituação dos assuntos tidos como básicos buscou-se especialmente por livros com publicação recente. Como publicação recente entende-se publicações de no máximo 5 anos passados. Como a tecnologia tem uma evolução muito rápida em poucos anos os livros podem não representar a situação atual para áreas como visão computacional, veículos autônomos e processamento de imagens. Uma exceção foi aberta a pesquisa sobre a sinalização das marcações nas rodovias brasileiras, que por não ter grande variabilidade utilizou-se como material de pesquisa um documento de 2010.

2.1.1 Visão computacional

A área da visão computacional, também chamada de visão de máquina, trata da reconstrução e interpretação de cenários reais através de imagens obtidas de câmeras digitais. Estes sistemas de visão de máquina em geral emulam o sentido da visão humana com foco em obter informações úteis destas imagens.(PETERS, 2017).

2.1.1.1 Contextualização

Estudos no campo de visão computacional são realizados a aproximadamente 50 anos mas ainda são um grande desafio para a ciência. Apesar de parecer trivial para seres humanos trata-se de uma tarefa muito complexa para computadores, pois existe uma grande lacuna de conhecimento entre os valores de um conjunto de *pixels* e um significado proveitoso. Para resolver este problema busca-se a compreensão da visão humana e transferência deste conhecimento para as máquinas. Analisando o sentido da visão pode-se resumi-lo em dois componentes principais, um dispositivo que capta o maior número de detalhes possível de uma

imagem, que para o caso humano são os olhos e em sistemas de máquina são as câmeras. E um segundo componente, que processa e retira significado desta imagens, que é representado por nosso cérebro e para visão computacional é um processador. Muitas pesquisas ainda são realizadas para entender todos segredos por trás da visão humana, entretanto, a visão computacional está longe do desempenho esperado. Os dados obtidos a partir de imagens são categorizados em informações de medidas e informações semânticas, sendo a segunda categoria detentora do maior número de dados. Com as medidas torna-se possível calcular distâncias e criar mapas do ambiente, e com os conhecimentos semânticos é possível rotular objetos, reconhecer pessoas, identificar ações, gestos e rostos.(KRISHNA, 2017).

2.1.1.2 Principais aplicações

Atualmente, existem câmeras por toda parte, com um número imenso de imagens transi-tando pela internet. A visão de máquina é responsável por classificar e gerar significado para estes dados. Apesar de ser uma tecnologia relativamente nova e ainda não atingir a eficiência da visão humana, muitas tarefas do dia a dia já utilizam-se deste conhecimento. O reconheci-mento de caracteres é uma das mais antigas aplicações da visão computacional e constitui-se da identificação de caracteres e números para leitura de códigos postais, reconhecimento de placas de veículos dentre outras funções. A detecção facial é outra atividade muito utilizada para melhorar fotos e focar nos rostos. Por fim, pode-se citar o uso em veículos autônomos que é uma das aplicações mais avançadas da visão computacional e já está sendo empregada em empresas como Google[®] , Tesla[®] e General Motors[®] que pesquisam para construção de carros totalmente autônomos.(KRISHNA, 2017).

2.1.2 Veículos autônomos

A evolução da tecnologia possibilitou grandes avanços no cotidiano, incluindo no setor automotivo. Esse desenvolvimento vem tornando veículos convencionais cada vez mais auto-matizados, ao ponto que conseguem dirigir parcialmente, e até, totalmente sozinhos. Pode-se atribuir a este processo de melhoria sistemas de aviso de colisão, controle de cruzeiro, esta-cionamento automático e outras tecnologias que já são vistas em veículos de alto padrão. O nível de automação atingido pelos veículos pode ser classificado entre 0 e 5 e está diretamente ligado a quantia de benefícios disponíveis. No nível 0 tem-se um veículo convencional, ou seja, sem nenhuma automação. Neste caso o motorista tem total controle sobre o carro sem qualquer auxilio tecnológico. Nos níveis 1 e 2 o motorista deve monitorar o sistema perma-

nentemente, incluindo o trânsito. Porém, a automação já assumi muitas tarefas na direção. O nível 3 inclui sistema de direção que não necessitam monitoramento contínuo e o próprio sistema solicita interferência do motorista. Com nível 4 os veículos tem controle total do veículo, mas o motorista ainda possui poder de anular decisões do sistema de direção. Já no último estágio, o veículo é totalmente autônomo e o motorista não tem influência nenhuma sobre o processo de direção.(HERRMANN *et al.*, 2018).

2.1.2.1 Finalidade e evolução

As grandes montadoras tem empregado grandes investimentos em pesquisas na área de automatização de veículos, com intuito de atingir o mais alto nível de automação de 5 a 20 anos. Existem muitas motivações que justificam esses investimentos. Como principais motivos destaca-se o grande número de mortos e feridos provenientes de acidentes causados por erro humano, redução de custos com congestionamentos, a possibilidade de duplicar ou até triplicar a capacidade das rodovias. Além disso, ainda há benefícios secundários como diminuição de padrões de testes de colisão que possibilitaria diminuir o peso dos automóveis, ou ainda, a diminuição do espaço gasto com estacionamentos, pois o próprio veículo poderia localizar uma vaga sozinho após deixar o usuário em seu local de destino.(ANDERSON *et al.*, 2016).

Após a apresentação realizada pela Google[®] de um carro sem qualquer motorista em 2010, houve um enorme crescimento de estudos sobre o assunto. Pesquisas realizadas indicam que as pessoas tem até duas vezes mais opiniões positivas sobre a direção autônoma do que em anos anteriores, que em geral referem-se a inteligência, segurança e modernidade. Há muita curiosidade e interesse de que esta novidade possa resolver os graves problemas relacionadas ao trânsito. Ultimamente, em especial na Europa e Ásia, muitos veículos autônomos já estão em uso no transporte de cargas e pessoas.(HERRMANN *et al.*, 2018).

2.1.2.2 Tecnologia utilizada

Para que seja praticável a automatização veicular é fundamental dispor de sensores que adquiram dados brutos sobre a realidade do ambiente. Estes dados coletados são interpretados por algoritmos, e partir disso, o automóvel é controlado. Para obter esta informação diversos sensores podem ser utilizados, incluindo câmeras, sistemas de detecção e alcance de luz, radares e outros como menor frequência. Os sistemas que utilizam visão computacional funcionam analogamente aos olhos humanos, com imagens. As câmeras são dispositivos baratos

e importantes neste processo, mas tem algumas limitações relevantes. Primeiro, os algoritmos de interpretação de imagens ainda não atingiram uma performance semelhante a dos olhos, e, em segundo lugar, as drásticas mudanças do ambiente trazem desafios para captar os dados, visto que as câmeras são calibradas para condições específicas e não se adaptam automaticamente as alterações. Os sistemas baseados em tecnologia de detecção de alcance de luz (LIDAR) também aparecem com grande destaque em sistema de veículos autônomos. Estes instrumentos emitem feixes de luz e determinam a distância até os objetos calculando o tempo de reflexão. As principais limitações destes equipamentos são o baixo alcance e dificuldade de refletir em determinados materiais. Os radares diferente dos sensores LIDAR transmitem ondas de rádio ao invés de luz, atribuindo diferentes características e limitações. Nestes casos as limitações de refletividade são ainda mais críticas que no sensor LIDAR, visto que objetos não metálicos tornam-se praticamente invisíveis aos radares. Como dito anteriormente existem outros sensores que são estudados como menor frequência na automatização veicular, porém todos tem as próprias vantagens e limitações. Como as características destes dispositivos já são conhecidas normalmente utilizam-se conjuntos destes equipamentos com intuito de complementar os pontos fracos uns dos outros.(ANDERSON *et al.*, 2016). Especialmente neste trabalho busca-se trabalhar com visão computacional e neste caso faz-se uso câmeras para captar imagens digitais. Para trabalhar com imagens digitais, que são consideradas dados brutos, realizam-se tratamentos de forma a facilitar sua análise. A este processo de tratamento de imagem dá-se o nome de processamento de imagem e será melhor explicado no próximo tópico.

2.1.3 Processamento de imagem

A área de processamento de imagem ocupa-se do tratamento de imagens digitais utilizando computadores. Este tratamento via máquinas, diferente da visão humana, permite atingir praticamente todo espectro eletromagnético e conseqüentemente alcançar uma ampla gama de aplicações. Não há um consenso entre os pesquisadores do ramo sobre o limite de atuação entre processamento de imagens e outros campos relacionados, como análise de imagens e visão de máquina. Para os autores processamento de imagem é definido por processos onde entradas e saídas são imagens, porém pode chegar a etapas ainda mais complexas como extrair atributos das imagens e até realizar reconhecimento de objetos, deixando a responsabilidade de dar sentido a estes dados aos campos de análise de imagens e visão computacional.(GONZALEZ & WOODS, 2018).

2.1.3.1 Imagens digitais

Imagens digitais podem ser representadas por uma função de duas dimensões do tipo $f(x, y)$, onde x e y simbolizam as coordenadas de posição no plano e a função F um valor de amplitude naquele ponto. Tendo em vista essa representação conclui-se que imagens digitais são constituídas de um número finito de elementos e cada elemento tem uma localização definida e um valor associado. Estes elementos são chamados de *pixels* e são os menores elementos de uma imagem.(GONZALEZ & WOODS, 2018).

2.1.3.2 Etapas de processamento

Para realização do processamento de imagem, o primeiro processo passa por adquirir esta imagem já em formato digital. Em geral, já no processo de aquisição é realizado uma primeira etapa chamada de pré-processamento que inclui tarefas como redimensionamento da imagem. A etapa de processamento basicamente realiza manipulações na imagem em questão de forma a ter melhores resultados que a imagem original dentro de uma aplicação específica. Pode-se dizer que não há uma regra de processamento de imagem, para cada operação existem suas próprias particularidades.(GONZALEZ & WOODS, 2018). Nas próximas subseções são discutidos brevemente alguns passos comumente utilizadas no processamento de imagens.

2.1.3.3 Filtros

Os filtros são uma ferramenta frequentemente empregada no processamento de imagens. Este processo divide-se em filtros espaciais e filtros no domínio da frequência. Os filtros espaciais executam a soma dos produtos entre a imagem e uma matriz de filtragem. O tamanho desta matriz define a vizinhança da operação e os valores da matriz influenciam na natureza do filtro. Este tipo de filtro cria alterações na imagem modificando o valor dos *pixels* por uma função que relaciona os valores dele e toda sua vizinhança. Filtros no domínio da frequência destinam-se a rejeitar, modificar ou dar passagem a frequências de luz específicas. Baixas frequências representam pontos da imagem com pouca ou lenta variação de intensidade de contraste e podem significar objetos como paredes ou mesmo o chão. Já altas frequências indicam rápidas variações de intensidade e representam bordas de objetos ou variações drásticas de intensidade de constaste. Trabalhando com estas frequências consegue-se destacar determinadas características em um imagem.(GONZALEZ & WOODS, 2018).

2.1.3.4 Segmentação de imagem

O processo de segmentação de uma imagem destina-se a limitação da área de interesse em um imagem, ou seja, cria-se um limite de pesquisa em uma região específica onde se tem certeza que determinada informação será encontrada. Normalmente essa tarefa tem um alto grau de dificuldade e de extrema importância, pois um processo de segmentação robusto e preciso facilita muito a classificação automática de objetos. Esse procedimento é separado em duas categorias, a primeira caracteriza-se por particionar as regiões levando em consideração mudanças drásticas de intensidade, enquanto na segunda categoria o particionamento dá-se de acordo com um conjunto de critérios pré-definidos.(GONZALEZ & WOODS, 2018).

2.1.3.5 Reconhecimento de objetos

A tarefa de reconhecimento de objetos trata da classificação de padrões dentro de uma imagem. Nesta etapa são atribuídos rótulos a objetos utilizando como base os descritores de recursos. São 3 as abordagens básicas para realizar reconhecimento de objetos: Classificar com base nas semelhanças de um protótipo específico e um padrão desconhecido, classificar através de dados estatístico ótimos e com redes neurais. Cada uma destas abordagens descritas diferencia-se pelo nível de engenharia necessário para tornar os dados brutos em dados legíveis para o processamento em computadores. Na classificação baseada em protótipos espera-se tornar os recursos únicos e de fácil detecção. A classificação pôr métodos estatísticos teóricos baseia-se na seleção de parâmetros que podem produzir desempenho de classificação ideal. Os classificadores que utilizam redes neurais tem a capacidade de gerar autonomamente representações para realizar o reconhecimento dos objetos. O diferencial destes sistemas é que eles conseguem produzir os recursos sem a necessidade de mão obra de engenharia.(GONZALEZ & WOODS, 2018).

2.1.4 Sistema de marcação de rodovias no Brasil

O Conselho Nacional de Trânsito (CONTRAN) é o órgão governamental que, dentre outras atividades, coordena, regula e normatiza as marcação nas vias rodoviárias, sendo o manual brasileiro de sinalização de trânsito o documento que formaliza diversas destas questões. Nesta seção são abordadas as normativas relacionadas a sinalização permanente de trânsito. A sinalização permanente tem o objetivo de ordenar, advertir e orientar os envolvidos no tráfego. Este tipo de sinalização é composta de painéis, marcações nas rodovias e outros equipamentos

auxiliares. Com isto busca-se chamar atenção dos usuários em tempo hábil para as reações necessárias, sendo assim, deve-se adicionar a sinalização em local e com dimensões apropriadas a necessidade exigida pelo ambiente rodoviário. Todos os materiais envolvidos nas marcações como chapas, tintas, estruturas de sustentação e dispositivos auxiliares são regulamentados pela associação brasileira de normas técnicas (ABNT). (DNIT, 2010).

2.1.4.1 Classificação de marcações rodoviárias

A sinalização permanente classifica-se em três principais categorias: vertical, semafórica e horizontal. Os indicadores verticais são feitos através de comunicação visual com placas, painéis e dispositivos auxiliares posicionados verticalmente. Estes equipamentos são instalados à margem das pistas ou suspensos, tendo como foco regularizar o uso da rodovia e advertir situações de risco. A sinalização semafórica com controle adequado torna-se muito útil para controle e segurança do tráfego de veículos e pedestres. E por fim, a indicação horizontal como o próprio nome sugere, são marcas, símbolos e legendas aplicados horizontalmente sobre as rodovias, concedendo segurança e conforto aos usuários. (DNIT, 2010). Nesta pesquisa será dado maior enfoque as marcações horizontais e por isso em seguida serão descritos maiores detalhes deste tipo de sinalização.

2.1.4.2 Sinalização horizontal

A sinalização horizontal destaca-se por permitir que o motorista obtenha informações e advertências sem que seja necessário tirar atenção da pista de rodagem. Além disso, vale salientar a grande importância na orientação para o tráfego noturno, pois permite a identificação dos limites da rodovia. Existe uma grande variedade de marcações, tanto em relação a forma quanto a cores. Com relação a cores estas sinalizações podem ser amarelas, brancas, vermelhas, azuis e pretas. A cor amarela destina-se a controle de estacionamento, sinalização de lombadas e indicação de sentido opostos da rodovia. A cor branca sinaliza pistas do mesmo sentido, delimita pistas e é utilizada para legendas, símbolos e setas. A cor vermelha demarca ciclovias e sinaliza locais reservados para estacionamento e parada. A cor azul é exclusivamente utilizada para sinalização de espaços reservados a portadores de deficiências físicas. E a cor preta é utilizada para aumentar o contraste de rodovias com pavimento claro, normalmente de concreto. Com relação a formato as marcações horizontais são categorizadas em longitudinais, transversais, de canalização, de delimitação e inscrições no pavimento sendo cada uma utilizada para uma situação específica que esta destacada na Tabela 1. (DNIT, 2010).

Tabela 1 Sinalização horizontal

Categoria	Funcionalidade
Marcas longitudinais	Separar e ordenar fluxo de veículos. Além de reger pontos de ultrapassagem
Marcas transversais	Ordenar movimentação dos usuários, induzir a redução de velocidade, sinalizar posições de parada em interseções e faixas de pedestres.
Marcas de canalização	Sinalizar alterações na trajetória normal do fluxo de veículos
Marcas de delimitação	Utilizada em conjunto com sinais verticais para marcar áreas de parada e estacionamento proibidos
Inscrições no pavimento	Setas, símbolos e legendas utilizadas em conjunto com outras sinalizações horizontais

Fonte: Elaborado pelo Autor.

Cada uma das categorias descritas na Tabela 1 possui uma variedade de marcações que não serão descritas individualmente por não ser o foco do trabalho. Maiores detalhes podem ser encontrados na documentação oficial que regula este tipo de sinalização. Em estudos que tem como objetivo a detecção de faixas é de suma importância entender o significado das diversas variações destas marcações, para que seja possível realizar ações seguras e condizentes com o ambiente rodoviário.

As pesquisas realizadas nesta seção vêm a somar com os conhecimentos desenvolvidos na etapa seguinte de trabalhos correlatos, com a finalidade de dar suporte na elaboração de algoritmos voltados para veículos autônomos que utilizam visão computacional para identificação de marcações nas pistas rodoviárias.

2.2 TRABALHOS CORRELATOS

As pesquisas de trabalhos correlacionados à este estudo foram realizadas na biblioteca digital IEEE Xplore. Foram feitas pesquisas preferencialmente nesta plataforma pois é voltada a pesquisas técnicas nas áreas de engenharia e tecnologia se tornando mais fácil de encontrar material. Foram feitas inicialmente pesquisas em português, mas devido ao baixo número de trabalhos encontrados optou-se em fazer as pesquisas em inglês. Neste segundo idioma foi localizada vasta base para pesquisa. Em busca de uma base sólida de pesquisa, iniciou-se o estudo com artigos que apresentem os principais temas e dificuldades que permeiam as técnicas de visão computacional.

Ranft & Stiller (2016) desenvolveram um estudo sobre uma visão geral da situação das

pesquisas na área de visão de máquina para veículos inteligentes. Isso se faz necessário, visto que, adquirir informações oriundas de câmeras não é uma tarefa trivial, principalmente, em comparação com outros sensores como radares, "*Light Detection and Ranging*"(LIDAR) e sensores ultrassônicos. Dirigir envolve uma grande gama de conhecimentos, dentre eles conhecer a posição e orientação do próprio veículo, de outros objetos envolvidos no tráfego, o reconhecimento de símbolos, além disso, realizar previsões a partir da cena atual do trânsito. Ao longo deste estudo foram descritas de forma breve as maneiras normalmente utilizadas para aquisição da "*early vision*", que segundo eles é a imagem preliminar de onde são retiradas todas as informações. Foram descritos métodos de localização do veículo via mapas, importante para navegação remota dos veículos, modos para realizar reconhecimento e classificação de objetos, formas para criar abstrações a partir das cenas captadas pelas câmeras, e por fim, maneiras de validar os dados construídos pelo algoritmo que automatiza o veículo. Neste trabalho busca-se dar luz as técnicas utilizadas por diversos pesquisadores, apresentando pontos fortes e fracos, mas não são realizadas comparações de desempenho entre esses métodos.

Realizou-se uma revisão e comparação entre algoritmos baseados em visão, voltados para detecção de linhas das rodovias. Segundo os autores, mecanismos de detecção de faixa são importantes para veículos semi-automáticos e um primeiro passo para automatização completa destes. A construção de um sistema de detecção do solo robusto é bastante desafiadora, principalmente, devido a grande variabilidade de condições do solo e do clima. O estudo propõem que sistemas de detecção de faixa devem ser compostos de alguns passos de pré-processamentos, divididos em filtro de imagem, detecção de características, aplicação do modelo, integração do rastreamento e tradução das coordenadas. Para cada uma destas etapas são descritos diferentes algoritmos utilizados por pesquisadores. Conclui-se que apesar da grande variedade de estudos e técnicas desenvolvidos ao longo dos anos, ainda existe muito a evoluir na detecção de faixas, principalmente quando são considerados os casos mais extremos do ambiente, como movimento dinâmico de objetos, linhas de marcação de má qualidade, curvas proeminentes, faixas com formas fora do padrão, etc.(FENICHE & MAZRI, 2019).

Shirke & Rajabhushanam (2017) realizam uma revisão das maiores dificuldades e métodos de detecção de estradas, visto que é um dos grandes desafios devido a alta variabilidade de cenários encontrados. Os principais desafios percebidos foram identificar veículos estacionados ou em movimento, reconhecer linhas com má qualidade, sobras em geral, curvas mais acentuadas, marcações ou escritas nas faixas, declives e objetos em meio as faixas, drásticas mudanças de cor das linhas, diferenças entre linhas contínuas e pontilhadas e condições ambientais como chuvas, neve, reflexo, etc. No estudo foram descritas brevemente uma grande gama de soluções encontradas por diversos pesquisadores, além disso, os autores citam quatro *datasets*

úteis para pesquisas na área de detecção de faixas que são: O *dataset* de estradas KITTI (*A project of Karlsruhe Institute of Technology and Toyota Technological Institute at Chicago*), o *dataset Caltech Lanes*, o conjunto de dados MSRC-21 e CamVid (*The Cambridge-driving Labelled Video Database*). Os autores concluíram que abordagens de comparação baseados em recursos exigem menor custo computacional, porém atingem piores resultados de precisão frente a abordagens baseados em modelos, e que, os algoritmos atuais tem bons resultados analisando estradas retas. Entretanto, ainda há muito a evoluir com relação a estradas com curvas acentuadas.

Deng & Wu (2018) propõem um sistema para auxiliar na segurança do trânsito, este sistema se justifica, pois a saída de veículos de sua pista é causa de 50% dos acidentes de trânsito na China, onde o estudo foi realizado. Grande parte destes acidentes podem ser evitados avisando os motoristas quando estiverem fora dos limites de sua pista. Para identificar a faixa de rodagem DENG & WU (2018) retiram da imagem o trecho que mostra apenas o céu, diminuindo a área de processamento. Em seguida a imagem é transformada em escala de cinza e filtrada utilizando o operador Candy, por fim, as linhas da pista são identificadas através da transformada de Hough. Durante o trabalho também foram apresentadas especificamente técnicas de identificação de curvas, que podem ser umas das grandes dificuldades na localização das linhas da faixa de rodagem. Esta técnica se mostrou bastante eficiente, pois diminuiu o tempo de processamento das imagens.

Construiu-se um algoritmo para reconhecimento de linhas baseado em visão computacional. Este algoritmo visa ser generalista, podendo ser aplicado a diferentes processos, como robôs para inspeção de dutos, veículos aéreos não tripulados, sistemas de auxilio para troca de pistas, etc. Para processar a imagem foi utilizado a placa de desenvolvimento raspberry PI, em conjunto com a biblioteca multiplataforma *OpenCV (Open Source Computer Vision Library)*. A imagem obtida pela câmera é convertida para escala de cinza e filtrada utilizando filtragem morfológica. Com a imagem previamente tratada são aplicados modelos de varredura em linha reta e elíptica. Para realização de testes de validação o algoritmo foi aplicado a um veículo quadrimotor, com imagens estáticas, ou seja, sem movimento. Considerando esta situação o sistema se mostrou bastante robusto, mas fica como trabalho futuro análises com veículo em movimento.(YANG *et al.*, 2016).

Dang *et al.* (2017) acreditam que em um futuro próximo veículos autônomos terão grande impacto no transporte de pessoas. Conhecendo a importância de detecção de linhas para estes veículos, eles propõem um sistema de detecção com rápido processamento e aplicabilidade. Nesta solução imagens com baixa resolução são utilizadas para verificação de linhas e outras de melhor qualidade para reconhecimento de objetos, sinais de trânsito e demais informações

que necessitem maior precisão. Isso é feito com intuito de diminuir o processamento para detecção das bordas da pista de rodagem. Este artigo sugere a utilização do algoritmo de redução de resolução (Algoritmo R2), que possui dois modos: O modo de iteração (modo-I) e o modo de limiar de cor (modo-c), onde o modo-I tem melhor qualidade de detecção e o modo-C melhor velocidade de processamento. O algoritmo preferencialmente executa sob o modo-C e em casos de mudanças bruscas do ambiente executa o segundo modo. Para implementação deste algoritmo foi utilizada biblioteca *OpenCV*. A imagem é convertida para escala de cinza, é aplicado transformada de "*bird view*", e utilizado o algoritmo Canny para detecção de bordas, além de, filtros de dilatação e erosão. Foram realizados testes em um carro de controle remoto, tendo uma raspberry PI como controlador. E um segundo teste com algoritmo completo em um Kit de controle para carro de passeio infantil, neste caso um laptop foi utilizado para controle e processamento. Devido a limitação de processamento da raspberry o algoritmo só trabalhou em modo-C, e mesmo neste modo simplificado obteve-se bons resultados. De modo geral o algoritmo foi eficiente, apresentou 100% de detecção no modo-I, e em modo-C apesar de alguns erros de identificação a segurança não é comprometida. Com relação a processamento, o algoritmo apresenta um considerável ganho de velocidade em comparação com a transformada Hough.

Kim *et al.* (2018) introduzem o método de detecção de solo e rodovia utilizando câmera estéreo para veículos auto guiados. O mapa de disparidade gerado por uso de duas câmeras facilita a extração de informações da imagem em comparação com câmeras únicas, em especial, quando há diversos veículos e objetos. A aplicação foi desenvolvida com programação dinâmica, filtro de Kalman e para cálculo do mapa de disparidade e processamento em geral foi utilizado um FPGA (*Field Programmable Gate Array*). Em geral o reconhecimento de pistas é relativamente fácil de ser realizado em pistas vazias e com poucos obstáculos, entretanto, isso dificilmente será uma realidade. Neste artigo foi apresentada uma maneira de criar um mapa de disparidade e melhorar a eficiência de sistemas de rastreamento de linha em situações reais de tráfego.

Foi desenvolvido um novo método para detecção de linhas e curvas de cores amarelas e brancas. Isto é proposto com intuito de melhorar o desempenho de sistemas de tráfego inteligente, com foco inclusive em linhas curvas. Nesta técnica são combinados o processamento das linhas amarelas em espaço de cores HSV ("*hue, saturation e brightness*") e o tratamento das linhas brancas em escala de cinza, além disso, são utilizados os algoritmos de detecção de borda Canny, transformada de perspectiva inversa e o método de ajuste de janela deslizantes. O sistema tem como principais características uma grande precisão na detecção de linhas amarelas e maior eficiência no rastreamento de curvas, devido a utilização do ajuste de janela

deslizante que supera a transformada de Hough em casos de linhas não retas. Esta estratégia mostrou-se robusta e eficaz para uma grande variedade de estruturas de pista. Como trabalhos futuros sugere-se a inserção de detecção de pedestre e sinais de trânsito.(FARAG, 2020).

Farag & Saleh (2018) desenvolveram um algoritmo voltado para rastreamento de pistas em sistemas de assistência avançada de direção ou carros autônomos. Deseja-se obter um algoritmo relativamente simples e com alta velocidade de processamento. Para execução deste trabalho utilizou-se uma câmera única presa em frente a um veículo, as imagens capturadas por esta câmera são convertidas em escala de cinza, aplica-se um filtro gaussiano *Blur* e o algoritmo Canny com limites automáticos, desta forma obtém-se o que eles chamam de “*edged image*”, ou em português, imagem com bordas. Esta imagem resultante é uma representação simplificada da original. Com intenção de melhorar a precisão na localização das linhas da pista é extraída uma ROI (*Regions Of Interest*), que neste caso é o trecho onde apenas a pista de rodagem aparece, ou seja, partes que constam o horizonte e externo da pista podem ser desconsiderados. A partir da ROI foi aplicada a transformada de Hough para determinar os segmentos de linha. O desempenho desta aplicação foi testado em diversas imagens estáticas e vídeos em tempo real. Como resultado o algoritmo realizou rastreamento de linhas bastante eficaz e com boa velocidade de processamento, exceto em situações onde a pista está coberta com padrões de sombras complexos.

Ibrahim *et al.* (2020) expõem um sistema de aviso de colisão, com objetivo de auxiliar veículos auto guiados a integrar-se ao trânsito na vida real. Este sistema está subdividido em quatro etapas: detecção de carros, estimativa de profundidade, determinação de posição do veículo nas pistas e técnica de rastreamento. Optou-se por construir o sistema com apenas uma câmera, modelo pré-treinado YOLO (*You Only Look Once*) em conjunto com *dataset COCO (Common Objects in Context)* para detectar carros e determinar a distância entre eles. Vale salientar que o modelo YOLO foi novamente treinado com imagens de veículos para melhorar o desempenho ao rastrear este tipo específico de objeto. A imagem foi dividida em três ROI, a pista atual do veículo, pista esquerda e direita. Sendo a pista atual considerada como área de emergência, e portanto, observada com maior interesse. Os testes foram realizados utilizando kit de circuito embarcado *Nvidia Jetson TX2* e vídeos de veículos reais em trânsito. Esta estrutura obteve precisão na avaliação de profundidade de 80,4 %, na determinação de faixa de 93% e cálculos de velocidade de 80,4%, isso a 23 FPS (*Frames Per Second*).

Zhou & Fan (2019) desenvolvem um sistema de identificação de veículos utilizando multi câmeras. Optou-se por uso de multi câmeras para reduzir as dificuldades encontradas no tratamento de imagens de câmeras únicas que são: insensibilidade às informações do ângulo do veículo, vulnerabilidade à oclusão e ângulo de visão limitado. A estrutura deste modelo

é construída por quatro módulos, a detecção de veículos para identificação dos objetos, o módulo de vinculação de veículos responsável por determinar a área da imagem à qual um automóvel específico pertence, o módulo de inicialização bilinear que determina a categoria de cada veículo e módulo de votação ponderada que mescla os resultados de cada câmera. Foram realizados experimentos com dois *datasets* diferentes: *KITTI Dataset test* e *Crawler dataset test*, ambos foram aplicados utilizando técnica de rede bilinear e votação ponderada. Onde o método de votação ponderada atinge 90,5 e 95,6 % de acurácia e a rede bilinear atinge 87,3 e 95,6 % de acurácia. Sendo que, apesar de ter menor precisão a rede bilinear tem melhor eficiência na identificação refinada de veículos.

Satzoda *et al.* (2014) constroem um algoritmo baseado em visão de máquina para auxiliar sistemas de segurança automotiva. Esta aplicação tem como objetivo ter uma grande eficiência computacional visando plataformas de *hardware* embarcado. Para garantir o ganho de processamento foram trabalhadas melhorias de calibração da câmera que podem reduzir custo computacional e da janela de amostragens, ou seja, são criados ROI ao invés de verificar a imagem como um todo. Essa técnica utiliza a calibração da câmera para gerar novos LUTs (*look up table*) de tamanhos diferentes da imagem base, para então aplicar janelas deslizantes. Para avaliar a performance desta técnica utilizou-se o conjunto de dados LISA e feito uma comparação com a técnica de reconhecimento de imagem passiva. Concluiu-se que foi possível obter um ganho de processamento de até 10 vezes e ter uma redução de alarmes falsos de 30%.

Zaarane *et al.* (2019) relatam uma estratégia simples e eficaz de medir distância entre veículos utilizando uma câmera estéreo. A distância é calculada através de derivações geométricas, distância entre as câmeras e análise de alguns ângulos específicos. A medição de distâncias em sistemas de direção autônoma é de extrema importância, pois com base nesta informação é calculada velocidade dos veículos e se tira diversas conclusões para tomada de decisão. Estes sistemas de medição de distâncias são basicamente divididos em visão mono que utilizam uma única câmera, mas em geral apresentam baixa acurácia e estéreo que utilizam duas câmeras que dão impressão de profundidade e aumentam o nível de acurácia do sistema. Neste artigo a identificação de automóveis foi feita via transformada Wevelet e classificador *AdaBoost* em apenas umas das câmeras, em um segundo momento, foi feita correlação cruzada identificando o mesmo veículo nas duas imagens captadas, e por fim, foi calculada as distâncias. Para determinar a distância ideal entre as câmeras foram feitos diversos testes em imagens com automóveis em distância conhecida. Após esta etapa de calibração pode-se dizer que o algoritmo é muito preciso em determinar a distância entre veículos.

Foi criado um método de estimar a distância entre automóveis com uma câmera de lente

única. Neste método identificou-se a área da estrada e o veículo dianteiro, e, calculado a distância entre ele e o automóvel onde está instalado o sistema. Este método baseia-se na detecção de bordas da estrada, geração do ponto de fuga, segmentação da área da estrada, detecção do veículo dianteiro e cálculo da distância. Para detecção de bordas foram combinados algoritmos de Canny, transformada de Hough e técnicas de filtragem. Para determinar o ponto de fuga foram feitos cálculos com " K "frames. Isso foi necessário pois o resultado da identificação de bordas gera diversas linhas de resultados possíveis, para solucionar este problema determinou-se que o ponto que tiver maior frequência de ocorrência seria eleito o ponto de fuga. O processo de segmentação da estrada é feito basicamente ligando as linhas direita e esquerda da pista ao ponto de fuga já eleito. E por fim, para localizar o automóvel dianteiro e calcular a distância utilizou-se o detector de bordas Sobel, técnicas de binarização, processamento morfológico e detector de segmento de linha. O método atingiu 71 % à 98 % de precisão na detecção de distância de veículos, sendo que as menores taxas foram observadas em ambientes mais complexos.(CHEN *et al.*, 2015).

Barua *et al.* (2019) propõem a utilização de câmeras para substituir a tecnologia LIDAR em veículos autônomos, pois o alto valor destes dispositivos inviabilizam o uso em larga escala. O sistema desenvolvido tem o objetivo de permitir a automóveis navegar com segurança, rapidez e eficiência em ambiente virtual. Foram realizados métodos de detecção de faixas, do tráfego, obstáculos, etc. Utilizando configuração de câmeras estéreo para cálculo de profundidade. Além disso, foi implementado controle de direção e trajetória. Para identificação de objetos e sua posição utilizou-se algoritmo YOLOv3. Para reconhecimento da pista foram aplicados filtros gaussianos e de limiar e empregado algoritmo RANSAC para ajuste do segmento de estrada. As coordenadas dos objetos foram determinada utilizando sistema de coordenadas Frenet, com isso foi possível fazer planejamento de trajetórias e controle do automóvel. Os testes de funcionamento foram simulados e apresentaram ótimos resultados. Como trabalho futuro pretende-se aplicar o algoritmo em sistemas reais, onde existem muitas outras variáveis que podem prejudicar sua assertividade.

Na Tabela 2 apresenta-se um resumo com as principais informações sobre os trabalhos correlatos pesquisados. Estes trabalhos estão organizados em cinco grupos: (A) Visão geral sobre os temas de visão computacional e detecção de estradas; (B) Abordagens sobre detecção de linhas das estradas; (C) Identificação de objetos; (D) Medição de distância entre os veículos; (E) Trabalho completo sobre veículos auto guiados. Dentro destas categorias eles foram classificados por ordem alfabética do nome dos autores.

Tabela 2 Artigos correlatos

Categoria	Autores	Título	Ano	Relação com estudo
A	Benjamin Ranft & Christoph Stiller	The Role of Machine Vision for Intelligent Vehicles	2016	Visão geral sobre as tarefas de visão computacional e métodos típicos
A	Mehdi FENICHE & Tomader MAZRI	Lane Detection and Tracking for Intelligent Vehicles A Survey	2019	Visão geral sobre algoritmos de detecção de linha para veículos autônomos
A	Suvarna Shirke & Dr.C.Rajabhushanam	A Study of Lane Detection Techniques and Lane Departure System	2017	Visão geral sobre métodos de detecção de pistas de rodagem e datasets para detecção do solo
B	Ganlu Deng & Yefu Wu*	Double Lane Line Edge Detection Method Based on Constraint Conditions Hough Transform	2018	Detecção de linhas no solo. Trata casos de linhas curvas
B	Huanhuan Yang <i>et al.</i>	A General Line Tracking Algorithm Based on Computer Vision	2016	Técnica e ferramenta para detecção de linha. Utiliza raspberry + câmera para entrada e tratamento dos dados
B	Li Dang <i>et al.</i>	Reduced Resolution Lane Detection Algorithm	2017	Algoritmo de detecção do solo
B	Jung-Gu Kim <i>et al.</i>	Road and Lane Detection using Stereo Camera	2018	Método de separação do solo e veículos usando múltiplas câmeras
B	Ziqiang Sun & Wael Farag	Vision Based Lane Detection for Self-Driving Car	2020	Algoritmo de detecção de marcas no solo
B	Wael Farag & Zakaria Saleh	Road Lane-Lines Detection in Real-Time for Advanced Driving Assistance Systems	2018	Transformada de Hough para detecção de linhas
C	Ahmed M. Ibrahim <i>et al.</i>	Real-Time Collision Warning System Based on Computer Vision Using Mono Camera	2020	Algoritmo para detecção de objetos com câmera única
C	ChunYue Zhou & TianYue Fan	A Vehicle Recognition Method Based on Multi-Camera Information	2019	Apresenta técnica de detecção de veículos usando múltiplas câmeras
C	Ravi Kumar Satzoda <i>et al.</i>	On-road Vehicle Detection with Monocular Camera for Embedded Realization Robust Algorithms and Evaluations	2014	Apresenta técnica de detecção de veículos usando câmera monocular
D	Abdelmoghith ZAARANE <i>et al.</i>	Vehicle to vehicle distance measurement for self-driving systems	2019	Técnica para estimar distância do veículo a frente
D	Chao-Ho Chen <i>et al.</i>	Front Vehicle Detection and Distance Estimation Using Single-Lens Video Camera	2015	Técnica de estimar distância do veículo a frente
E	Bhaskar Barua <i>et al.</i>	A Self-Driving Car Implementation using Computer Vision for Detection and Navigation	2019	Construído carro autônomo, com detecção de objetos, de linha. Todos testes realizados em ambiente simulado

Fonte: Elaborado pelo Autor.

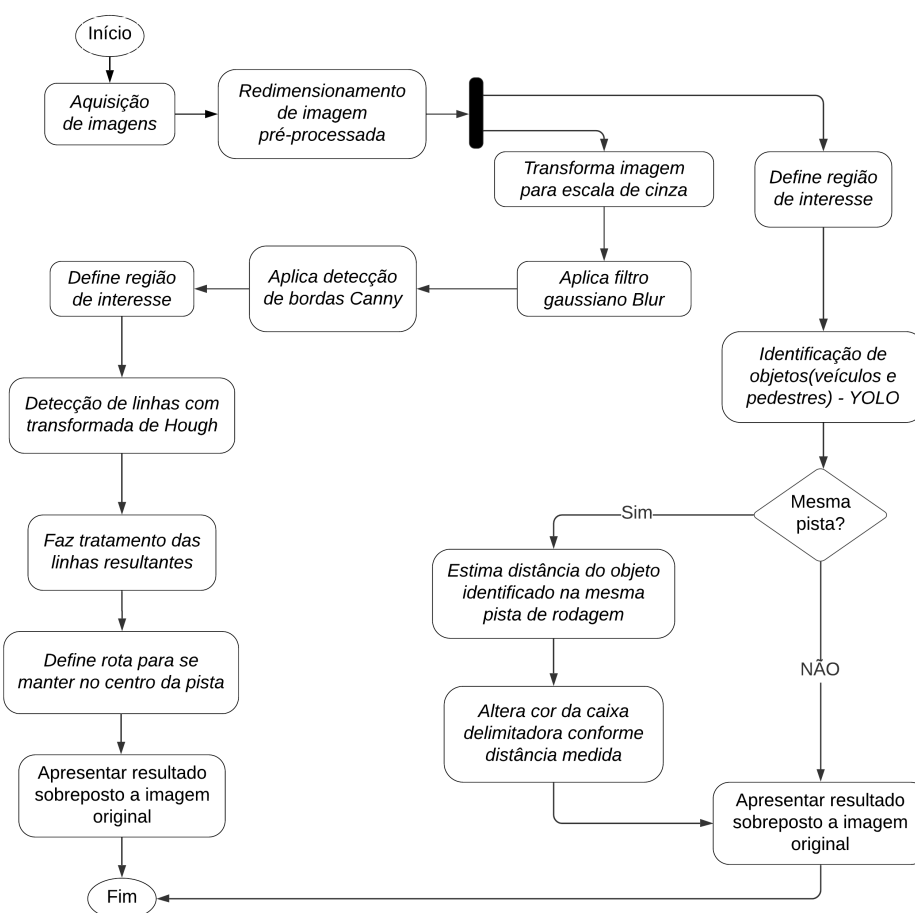
Tendo em vista os diversos trabalhos analisados, pode-se perceber que existem inúmeras maneiras para solucionar as dificuldades envolvidas no desenvolvimento de veículos autônomos e sistemas similares. Mas em geral, todos autores trabalham na aplicação de diferentes conjuntos de algoritmos para aumentar a eficiência e velocidade de processamento nas mesmas tarefas, ou seja, os problemas envolvendo detecção de linhas das estradas, identificação de veículos e sinais de trânsito, cálculos de distâncias e planejamento de trajetos já são bem conhecidos e difundidos entre os pesquisadores. Além disso, alguns algoritmos e técnicas aparecem repetidas vezes entre as resoluções. Diversos dos sistemas desenvolvidos neste ramo destinam-se a preocupações com a segurança de motoristas e pedestres sendo sistemas totalmente autônomos ou mesmo de auxílio à direção. Ambos são muito bem vindos para o cenário atual do trânsito e tem potencial para diminuir o número de acidentes. Toda iniciativa ou pesquisa que vise mitigar o número de colisões, e conseqüentemente, o número de vítimas foi válida e deve ser incentivada. No capítulo 3, será detalhado quais as abordagens foram aplicadas na condução deste estudo.

3 METODOLOGIA

Neste capítulo são apresentadas as propostas de projeto e validação para realizar a detecção de rodovias e objetos utilizando imagens e executar a estimativa de distanciamento do objeto detectado a frente. Esta seção está subdividida em 4 etapas, o diagrama de blocos contendo a estratégia de solução proposta, um infográfico apresentando as principais etapas de projeto para elaboração do sistema, um fluxo de testes e validação do sistema, e por fim, a apresentação do *set* onde o aplicativo foi construído e testado.

O diagrama exposto na Figura 1 contém a estratégia proposta para atingir todos objetivos anteriormente expostos. Cada bloco representa um estágio importante para atingir um sistema assertivo e eficiente.

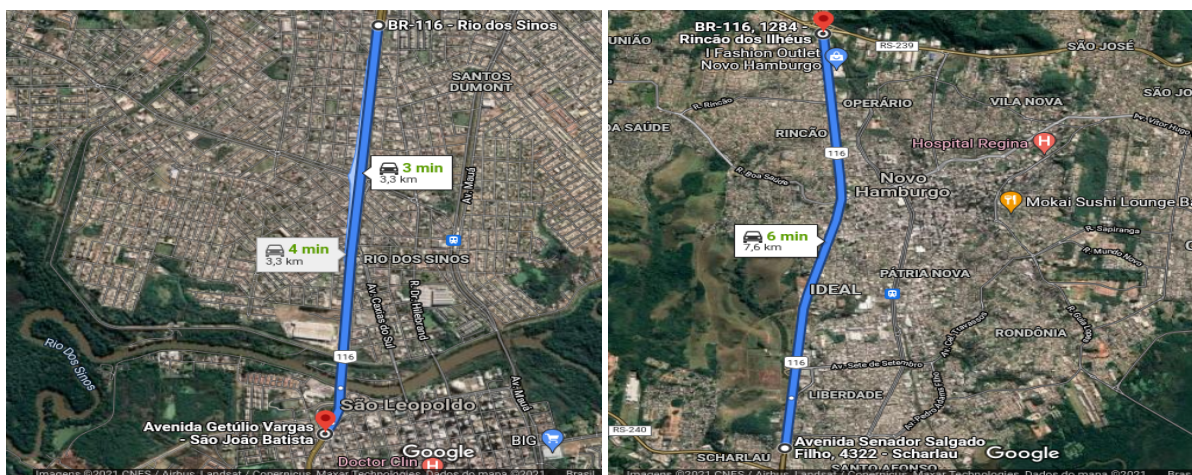
Figura 1 Diagrama de blocos



Fonte: Elaborado pelo Autor.

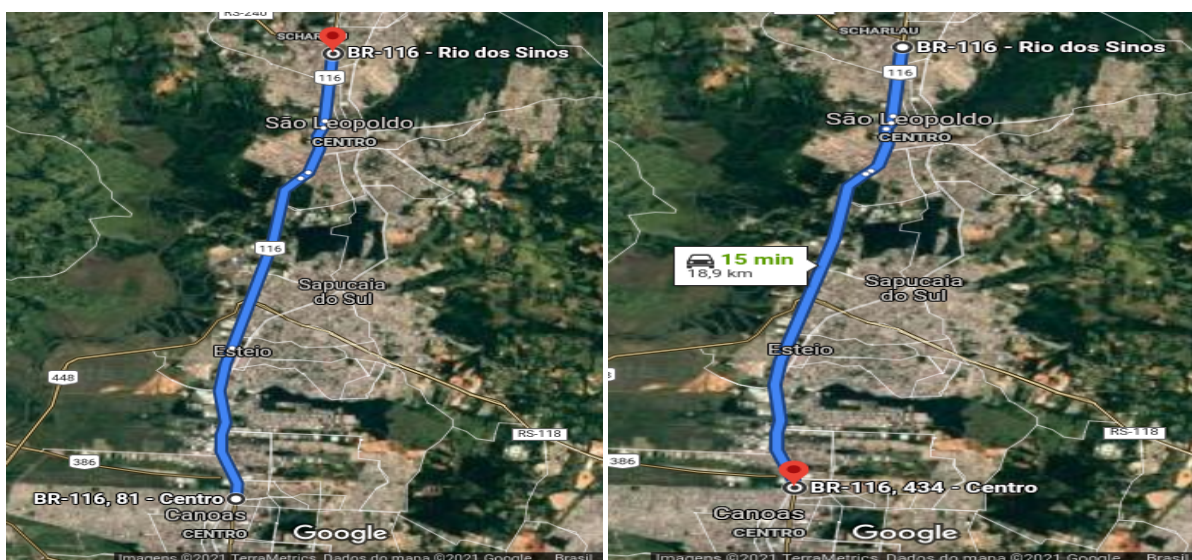
Primeiramente é preciso adquirir os dados, que para este caso são as imagens de rodovias. Estas imagens serão gravadas pelo próprio autor em condições de clima e trânsito diversas. As gravações são condicionadas a trechos da BR 116 compreendidos entre as cidades de Novo Hamburgo e Canoas no Rio Grande do Sul, pois possuem marcações horizontais bem definidas que são requisitos mínimos para funcionamento da aplicação. Na Figura 2 estão demarcados os trajetos específicos nos quais foram gravados os vídeos.

Figura 2 Trajetos realizados para aquisição de dados



(a) São Leopoldo para São Leopoldo

(b) São Leopoldo para Novo Hamburgo



(c) Canoas para São Leopoldo

(d) São Leopoldo para Canoas

Fonte: Fonte Google Maps.

Com estes dados em mãos inicia-se a etapa de processamento destas imagens, que consiste basicamente em alterar alguns atributos da imagem com intuito de destacar características pontuais, vale destacar que o aplicativo trata todo o vídeo *frame a frame*. Dentro desta etapa está incluso o redimensionamento da imagem para que assuma as dimensões da tela do dispositivo que estiver executando o aplicativo. Esse bloco foi necessário pois os vídeos obtidos nas gravações possuem dimensões maiores que a tela do computador. Para alcançar uma solução genérica, ou seja, que atenda a outros dispositivos, o aplicativo capta a resolução da tela onde estiver sendo utilizado e atribui essa nova dimensão ao vídeo.

A imagem redimensionada passa por dois processos, um de pré-processamento para ser utilizada na identificação de linhas da pista e previsão de rota, e um segundo, de identificação de objetos e estimativa de distância. Inicialmente será exposto o primeiro processo que têm como primeiro passo a transformação do vídeo em escala de cinza. Esta transformação é feita pois em geral os detectores de borda que são apresentados a frente trabalham com imagens em tons de cinza, ou seja, o sistema de cores, tradicionalmente nas cores vermelho, verde e azul é simplificado para um único valor de intensidade de cinza. Para melhorar esta imagem e obter melhores resultados no detector de borda é utilizado um bloco de filtro Gaussiano do tipo *Blur*, este filtro faz a suavização da imagem minimizando os efeitos de ruídos gerados durante aquisição da imagem, limitação de *hardware* ou mesmo durante digitalização. Foram feitos testes com filtros Sobel e Laplaciano, porém ambos geraram imagens com pior qualidade.

Após este tratamento a imagem passa por um detector de bordas Canny que identifica mudanças abruptas de intensidade de *pixels* e desta forma consegue localizar linhas de borda em uma imagem. Espera-se com isso que seja possível destacar a localização das linhas de referência da rodovia.

Com intuito de diminuir o custo computacional do sistema optou-se por criar uma região de interesse onde seja possível observar apenas as linhas de referência da pista e o que estiver compreendido dentro de seus limites, excluindo desta forma as áreas laterais e do horizonte. São feitos testes com geometrias diversas tendo como indicador de qualidade o número de *frames* por segundo (FPS) que são tratados. Para definir uma região de interesse em imagens em escala de cinza é criada uma "máscara" onde os pontos que não interessam a aplicação possuem valor zero, ou seja, são pretos e os que interessam são iguais a 255 que correspondem a cor branca, em seguida essa máscara é combinada bit a bit com a imagem original que gera o efeito de transformar em preto toda área não interessante. Optou-se por aplicar a região de interesse após a execução do detector de bordas pois, se fizer o contrário a própria borda da região de interesse é identificada como uma possível borda da imagem.

Tendo a região de interesse definida é aplicada transformada de Hough neste área. Essa transformada é uma técnica matemática utilizada para detecção de formas geométricas em imagens digitais. Essa técnica considera a Equação 3.1 que defini a equação de reta.

$$y = ax + b \quad (3.1)$$

A partir dela usa-se uma matriz acumuladora $A(a, b)$ para armazenar os valores dos parâmetros a e b calculados para cada pixel não nulo. Se houver alguma correspondência de parâmetros da matriz A entre algum dos *pixels*, entende-se que há uma reta que passa por estes dois ou mais pontos. A função que executa a transformada de Hough retorna um vetor com todas linhas encontradas na área, este vetor é construído de tal forma que cada posição corresponde as coordenadas x inicial, y inicial e x final, y final de cada linha, ou seja, as coordenadas do ponto inicial e final de cada reta encontrada. Esta função permite também algumas parametrizações, como por exemplo o comprimento mínimo para que seja considerado uma linha e o máximo espaço que entende-se ser a mesma linha. Configurando adequadamente estes e outros parâmetros foi possível obter uma triagem inicial de linhas pertinentes a aplicação. Após obter-se este vetor de coordenadas é preciso fazer um tratamento nestes dados, visto que se faz necessário organizar quais coordenadas correspondem a linhas da esquerda ou da direita e eliminar linhas que não possuem informações relevantes ou são redundantes. Para identificar a qual lado da rodovia pertence a linha é realizado um comparativo do ponto x inicial do vetor e classificado conforme seu valor, já para eliminar valores redundante para cada *frame* é feito a média de cada uma das coordenadas das linhas, resultando em apenas uma linha para cada lado da pista.

Conhecendo as coordenadas iniciais e finais das linhas de referência da pista calculam-se os coeficientes a e b , descritos na Equação 3.1 de cada uma destas retas. Para isso considerou-se as Equações 3.2 e 3.3.

$$a = (y_{final} - y_{inicial}) / (x_{final} - x_{inicial}) \quad (3.2)$$

$$b = y_{inicial} - (a * x_{inicial}) \quad (3.3)$$

A partir das retas que descrevem as linhas de referência da rodovia pode-se definir o ponto onde elas se cruzam, ou seja, o ponto de fuga. E desta forma, indicar ao veículo qual correção de rota deve ser feita para se manter no centro da rodovia. Para calcular o ponto de fuga considerar Equação 3.4.

$$Rota = (bdireita - besquerda)/(aesquerda - adireita) \quad (3.4)$$

Por fim, tanto as linhas de referência quanto um indicador de rota são plotados sobre a imagem de saída para o usuário.

O segundo processo pelo qual a imagem original passa é pela detecção de objetos. Neste processo primeiramente defini-se uma região de interesse tendo como alvo apenas a área da rodovia a frente do veículo e com dimensões suficientes para enquadrar um veículo bastante próximo. Assim como na etapa anterior essa criação desta região tem como objetivo diminuir o custo computacional pois diminui a área de execução do algoritmo de detecção de objetos, além de diminuir a poluição visual da imagem eliminando detecções irrelevantes para condução do veículo em questão.

Após a definição da região de interesse a imagem passa por um algoritmo de detecção de objetos que atualmente é o estado da arte neste quesito. Este algoritmo chama-se *You only look once* (YOLO) que é um algoritmo de código aberto para detecção em tempo real de objetos e inclusive foi utilizado em alguns dos trabalhos mais atuais descritos no capítulo 2 na etapa de trabalhos correlatos. Este algoritmo aplica uma rede neural única em toda imagem, dividindo a imagem em regiões e prevendo caixas delimitadoras e probabilidades para cada uma delas. Essa rede neural é um modelo pré-treinado e pode ser treinado para algum objeto específico caso precise de uma assertividade maior que obtida, para esta aplicação não será realizado nenhum treinamento especial. Este algoritmo de detecção é distribuído em diversas versões, para este caso será utilizado *YOLO V2 tiny*, foi escolhida esta versão principalmente por limitação de *hardware*, visto que existem 5 versões e diferente desta utilizada não são do tipo simplificada *tiny*. Como saída desta etapa é obtida a imagem com as caixas delimitadoras ao redor dos objetos detectados, além do nome do objeto detectado e percentual de certeza desta previsão.

Por padrão as caixas delimitadoras geradas pelo algoritmo são de coloração preta. Entretanto deseja-se que a caixa seja laranja se estiver na mesma pista que o veículo usuário da aplicação e vermelha, em caso de estar a uma distância de 22 metros ou menos. Essa distância de 22 metros indica a distância percorrida durante tempo de reação de um motorista a uma velocidade de 80 km/h, de acordo com dicas de direção defensiva. Para fazer esta distinção usa-se o ponto de fuga calculado no processo anterior, caso este ponto esteja contido entre o ponto x máximo e mínimo da caixa delimitadora indica que o veículo está na mesma pista, caso contrário o veículo está em outra pista da rodovia. Ainda para os veículos presentes na mesma pista, utiliza-se os conceitos de distância focal e uma relação desta distância com número de *pixels* que compõem a caixa delimitadora e a largura real dos veículos para estimar a distância do objeto, conforme Equação 3.6. Onde a distância focal pode ser calculada utilizando a Equação 3.5.

Apesar da largura dos veículos ser variável, definiu-se um valor padrão de largura de 172 mm, este valor foi obtido fazendo uma média da largura de 205 modelos de carros de várias marcas. Com o valor de distância é possível identificar quando alterar a cor da caixa para vermelho, além de indicar a informação de distância na parte inferior da caixa delimitadora. Lembrando que a distância só será calculada para objetos na mesma linha do veículo.

$$Distanciafocal = (w/2) * cot(O/2) \quad (3.5)$$

Para w = Largura da imagem em *pixels* e O = ângulo de visão horizontal da câmera.

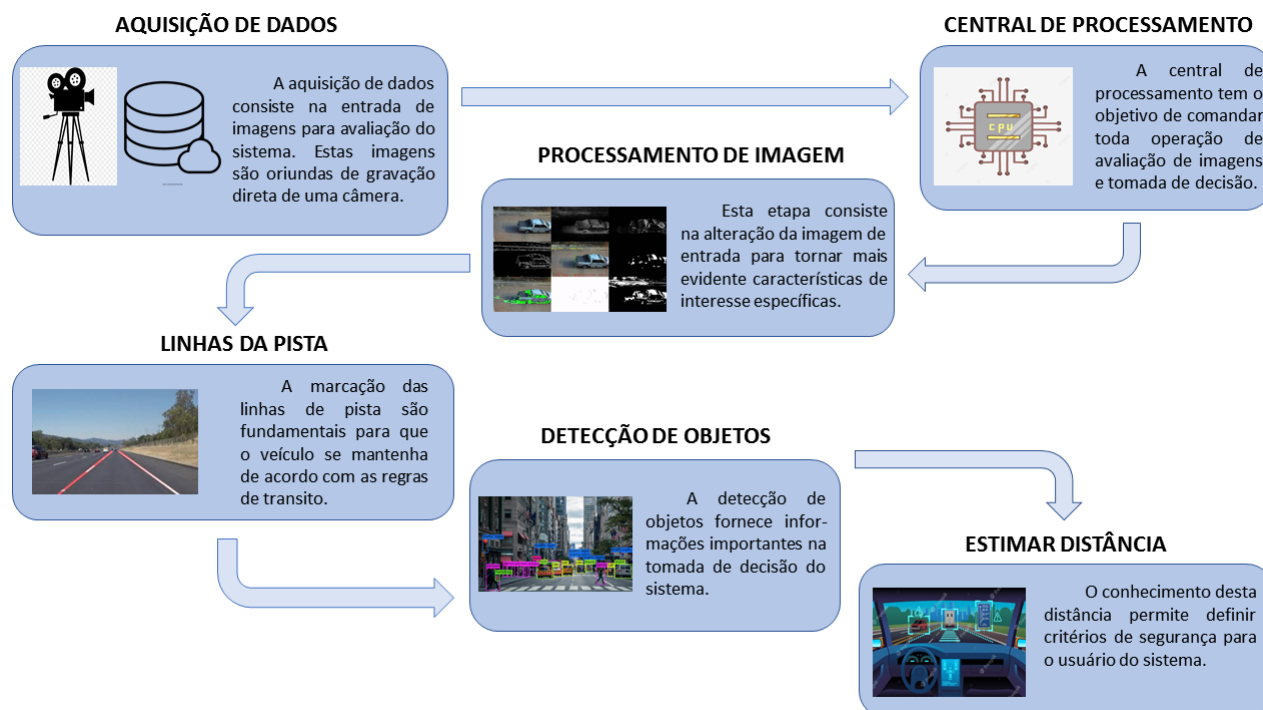
$$Distancia = f * W/P \quad (3.6)$$

Para f = distância focal da câmera, W = largura do objeto na vida real e P = largura do objeto em *pixels*.

O resultado final desta aplicação será um somatório da saída dos dois processos descritos, ou seja, será a imagem original, com a marcação das linhas de referência da pista, marcação que indica ponto central da pista, caixas delimitadoras nos objetos localizados na imagem, indicando a classe do objeto e probabilidade de certeza. Além da indicação de distância e alteração na coloração da caixa delimitadora para veículos localizados na mesma pista de rodagem que o usuário.

No infográfico construído na Figura 3 estão destacados pontos importantes do projeto. Esta figura evidencia a ordem cronológica de projeto e exemplifica através de imagens o resultado esperado em cada etapa.

Figura 3 Infográfico do projeto



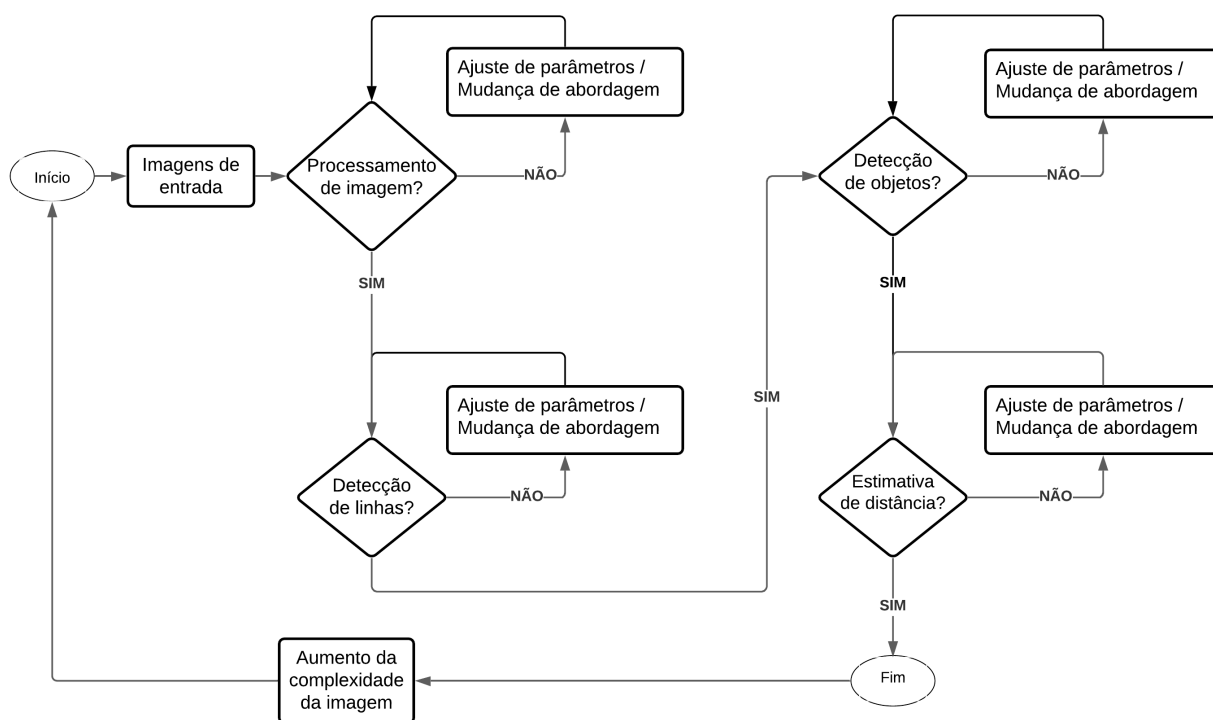
Fonte: Elaborado pelo Autor.

Com relação a aquisição dos dados, como dito anteriormente foram utilizados vídeos de autoria própria. Preferiu-se executar testes diretamente com vídeos pois o tratamento de imagens estáticas utilizam diferentes funções, logo para evitar retrabalho esta foi a abordagem adotada. Em seguida foi preciso definir o controlador que faz todo processamento e análise dos dados. Este dispositivo é muito importante, pois dependendo do poder de processamento disponível algoritmos mais robustos podem ser utilizados. Caso contrário técnicas para diminuir o custo computacional devem ser adotadas. Neste caso, preferiu-se utilizar um computador pessoal ao invés de placas de desenvolvimento e circuitos dedicados, por praticidade e por possuir relativamente bom poder computacional. A etapa de processamento de imagem como dito anteriormente inclui mais de um processo propriamente dito. Nesta etapa foram definidos os algoritmos de filtro, as técnicas que são adotadas para segregação da região de interesse na imagem e qual sistema de cor trará maior facilidade aos processos seguintes.

Após o processamento da imagem a localização de linhas na pista de rodagem foi feita com transformada de Hough, técnica bastante difundida para este tipo de aplicação. Para a detecção de objetos foi definido uso de um rede neural convolucional pré-treinada com intuito de facilitar o processo. Pretende-se ajustar o algoritmo escolhido de forma de consiga identificar pessoas e veículos conforme exemplificado na imagem presente no infográfico. O último desafio do projeto foi a estimativa de distância dos objetos detectados que deu-se por uma série de relações das características da câmera e aproximações das dimensões reais de veículos.

Com o sistema definido e parametrizado uma série de testes e avaliações foram realizados para validar o resultado. Este fluxo de testes pode ser observado na Figura 4 e está melhor descrito no próximo parágrafo.

Figura 4 Fluxo de testes / validação



Fonte: Elaborado pelo Autor.

Cada etapa descrita no fluxo de projeto é testada individualmente, desta forma são 4 principais blocos de testes, onde só será adicionada novas funcionalidades ao sistema ao passo que o bloco anterior tenha apresentado resultados satisfatórios. Em caso de não atingir bons resultados novas técnicas ou ajustes nos parâmetros são implementados e o teste é realizado novamente. Após aprovação de todos estágios, imagens mais complexas são adicionadas como entrada tornando o sistema mais eficiente. Inicialmente são realizados todos testes com imagens em ambiente favorável, ou seja, durante o dia e com sol, em seguida imagens mais complexas durante a noite, com chuva e com muita iluminação.

Com relação ao set de teste, a aquisição das imagens foi realizado com a câmera traseira de um celular modelo Xiaomi MI PLAY[®], com especificações detalhadas na Tabela 3. A câmera foi fixa com suporte veicular de celular, localizado na área central do para-brisas, logo abaixo ao retrovisor. Para captura dos vídeo foi utilizado o aplicativo *Droid Dashcam*, este aplicativo possui um velocímetro via *Global Positioning System* (GPS) integrado diretamente no vídeo e é de fácil utilização.

Tabela 3 Informações técnicas da câmera

Recursos	Flash LED, HDR
Vídeo	1080p@ 30fps
Configuração	12 MP, f/2.2, 1.25 um, PDAF + Sensor de profundidade secundário
Resolução	16:9
Ângulo de visão	78° (horizontal) e 49° (vertical)

Fonte: Elaborado pelo Autor.

Para desenvolvimento da aplicação optou-se pela linguagem de programação Python[®] por se tratar de uma linguagem popular na área de visão computacional tendo suporte para diversas bibliotecas e funções que facilitam a codificação. Além disso, o contato com esta linguagem é de interesse do autor. Esta é uma linguagem de alto nível difundida em várias áreas em especial por sua grande gama de ferramentas e bibliotecas *open source*, além de ser de fácil integração e interpretação.

Como processador fez-se uso de um notebook Samsung[®] modelo np370e4k que tem suas especificações descritas na Tabela 4. Este computador é equipado com processador I5 de 5ª geração, 8 GB de Memória RAM e 1 TB de armazenamento.

Tabela 4 Informações técnicas do notebook

Processador	Intel Core I5-5200u com 2,2 GHz
Memória RAM	8 GB
Tipo de memória	DDR3
Armazenamento	1 TB
Sistema operacional	Ubuntu 20.04

Fonte: Elaborado pelo Autor.

Conforme percebido no capítulo 2 existem diversas abordagens e técnicas que podem ser adotadas com sucesso cabe ao projetista selecionar as que melhor se adaptam aos objetivos propostos. No capítulo 4 está descrito os resultados obtidos após aplicar a metodologia proposta.

4 ANÁLISE E RESULTADOS

Esta seção apresenta os resultados obtidos após recorrer a metodologia discutida no capítulo 3. Espera-se com as técnicas empregadas atingir a todos objetivos inicialmente propostos. Este capítulo está dividido em 4 tópicos principais, onde são apresentados resultados separadamente da etapa de pré-processamento, identificação de linhas, detecção de objetos, estimativa de distâncias e resultado final da aplicação.

4.1 Pré-processamento

O pré-processamento inclui os estágios de filtro da imagem, detecção de bordas e determinação de região de interesse. Todos de suma importância para melhorar os resultados dos blocos de detecção.

Para o filtro da imagem foram realizados testes com diferentes filtros, mas o que gerou melhores resultados de diminuição de ruído foi o filtro do de suavização Blur. Este filtro adotado no pré-processamento demonstrou ótimos resultados como pode ser observado na Figura 5, isso fica ainda mais claro ao ver o retorno da etapa de detecção de bordas.

Figura 5 Filtro Blur



Fonte: Elaborado pelo Autor.

Após a etapa de filtro a imagem passa pelo detector de bordas Canny, onde espera-se que as linhas de referência da pista estejam nítidas e sem presença de ruídos. Conforme os resultados obtidos na Figura 6 pode-se perceber que o detector é bastante preciso e atende as expectativas.


Figura 6 Detector de bordas Canny



Fonte: Elaborado pelo Autor.

Finalizando o pré-processamento da imagem, determina-se uma região de interesse com formato definido de tal forma que englobe a maior parte das linhas de referência excluindo outros objetos do ambiente. Como dito anteriormente isso se faz necessário para melhorar o desempenho da aplicação quanto a velocidade de processamento. Foram feitos testes com algumas outras geometrias, mas a que atingiu melhores resultados foi a geometria trapezoidal conforme Figura 7.

Figura 7 Regão de interesse



Fonte: Elaborado pelo Autor.

Com o processo de pré-processamento concluído e demonstrando bom desempenho o próximo passo é a execução de testes na etapa de detecção de linhas da pista.


4.2 Identificação de linhas

A detecção de linhas é um dos objetivos principais do trabalho, neste caso são realizados testes de funcionamento em diferentes condições climáticas. Inicialmente foi feita detecção durante um dia ensolarado, em seguida durante a noite com chuva leve, e por fim, durante a noite com chuva intensa.

Na Figura 8 está representada a saída da função de detecção de linhas, ou seja, logo após aplicar a transformada de Hough, tratar os dados e plotar as linhas encontradas e linhas que marcam o ponto de fuga. As linhas em amarelo representam a marcação do ponto de fuga, que indica a rota para se manter no centro da pista. Como não existe um *feedback* de posição ou um controle da posição propriamente dito, este volante virtual é posicionado no centro das linhas de referência assim que a aplicação reconhece linhas dos dois lados da rodovia, logo pode acontecer de o vídeo iniciar em algum trecho que não tenha linhas perceptíveis aos dois lados e o volante aguarde a primeira referência para se posicionar.

Outra ação tomada é gerar um reposicionamento do volante em casos da correção de posição atingir valores maiores que 30 pixels , isso simularia que o motorista recebeu a informação de reposicionar e corrigiu sua rota para posição solicitada. Quando não são reconhecidas linhas dos dois lados a posição da linha de rota permanece em seu ponto zero que é o valor central da pista setado na primeira detecção.


Figura 8 Detecção de linhas



Fonte: Elaborado pelo Autor.

As linhas verde e magenta representam respectivamente as linhas a direita e a esquerda do veículo que está sendo conduzido. Elas são utilizadas para guiar o veículo e determinar os limites da pista de rodagem. Estas e as linhas de determinação de rota são plotadas sobre a imagem original demonstrando o que o aplicativo percebe do ambiente como pode ser observado na Figura 9. Esta primeira figura representa o resultado da identificação de linhas em um dia com condições bastante favoráveis a detecção, pois é um dia ensolarado, sem sobras ou reflexos que possam gerar grandes dificuldades. Como resposta tem-se as linhas de referência bem definidas e o volante virtual posicionado corretamente e apontando ao ponto de fuga.


Figura 9 Sobreposição das linhas detectadas



Fonte: Elaborado pelo Autor.

Em um segundo momento representado na Figura 10 foram realizados experimentos durante a noite e com chuva leve, neste caso ainda foi possível ter uma boa representação das linhas da pista e do posicionador.


Figura 10 Teste durante a noite e com chuva leve



Fonte: Elaborado pelo Autor.

Em busca de testes ainda mais severos o sistema foi exposto a chuva intensa demonstrado na imagem 11. Neste caso em específico sempre que o limpador de para-brisas não conseguia impedir um acumulo de água a linha não era identificada, isso não acontece em todo percurso e em alguns *frames* o reconhecimento das linhas ainda foi possível. É importante dizer que nesta situação houve dificuldades de visualização até mesmo para um condutor humano.

Figura 11 Teste durante a noite e com chuva intensa



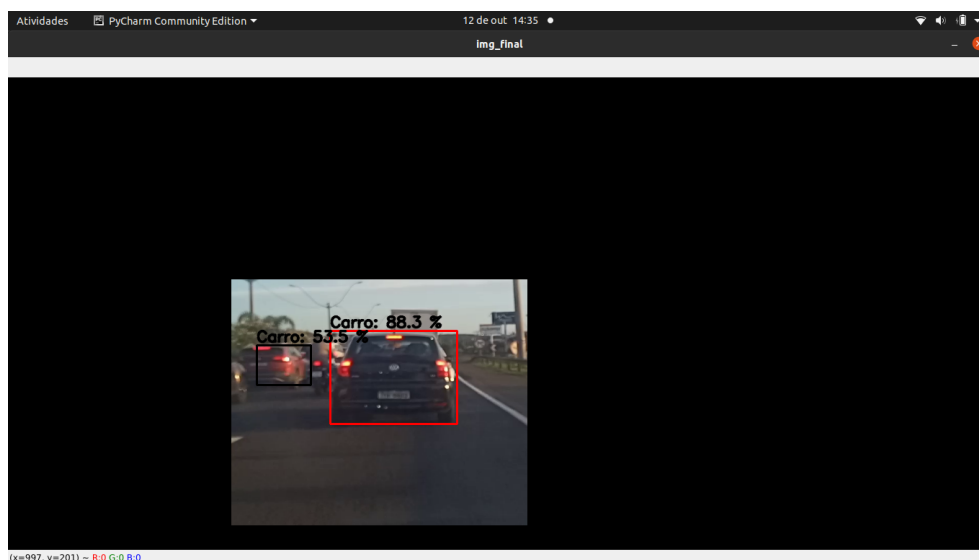
Fonte: Elaborado pelo Autor.

Com o processo de detecção de linhas bem definido e com resultados muito bons parte-se para o próximo tópico.

4.3 Detecção de objetos

O processo de detecção de objetos também passou por experimentos semelhantes a etapa de identificação de linhas. Para este caso foi definida uma área de interesse para aplicar o algoritmo. Isso é perceptível nas imagens 12, 13 e 14 onde apenas uma janela da imagem é perceptível, os demais pontos são suprimidos para diminuir tempo de processamento. Primeiramente, assim como no processo anterior foi realizado experimento em dia ensolarado e obteve-se bons resultados quanto a detecção e percentual de certeza demonstrado na Figura 12.


Figura 12 Detecção de objetos



Fonte: Elaborado pelo Autor.

A Figura 13 demonstra os resultados para vídeos gravados durante a noite e com chuva leve. Neste caso ainda foi possível alcançar os objetivos quanto a detecção de veículos, não tendo grande diferença com relação ao teste anterior.

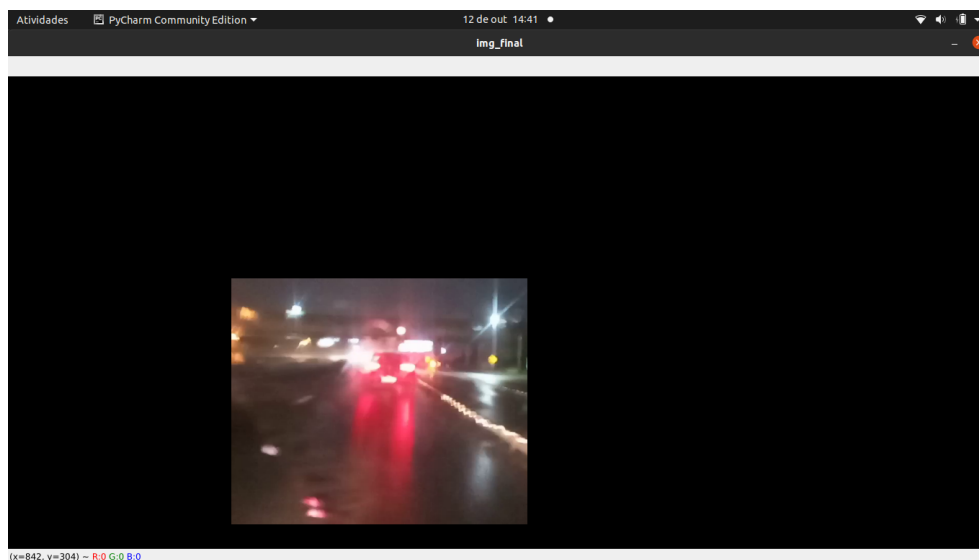
Figura 13 Detecção de objetos durante noite e chuva leve



Fonte: Elaborado pelo Autor.

Por fim, realizou-se teste com vídeos gravados durante a noite e com muita chuva, visto na Figura 14. Neste caso o sistema teve ainda mais dificuldades do que o processo de detecção de linhas, pois dificilmente foi possível localizar algum veículo. Devido ao grande volume de chuva considerou-se aceitável a dificuldade do sistema neste tipo de condição.

Figura 14 Detecção de objetos durante noite e chuva intensa



Fonte: Elaborado pelo Autor.

A detecção de objetos se mostrou bastante eficiente considerando que apenas em condições bastante extremas o sistema não conseguiu fazer a identificação dos veículos.

4.4 Estimativa de distâncias

O último objetivo proposto é a estimativa de distância dos veículos. Para validação do método de medida descrito no capítulo 3 foi gravado um vídeo de um veículo com nove distâncias conhecidas de 3, 5, 8, 10, 12, 14, 16, 18, 20 metros. O vídeo foi gravado na posição inicial de 3 metros e após certo período de tempo em cada distância deslocado até a posição final de 20 metros. Para estas distâncias o método de cálculo proposto atingiu os resultados demonstrados na Tabela 5.

Tabela 5 Estimativa de distâncias

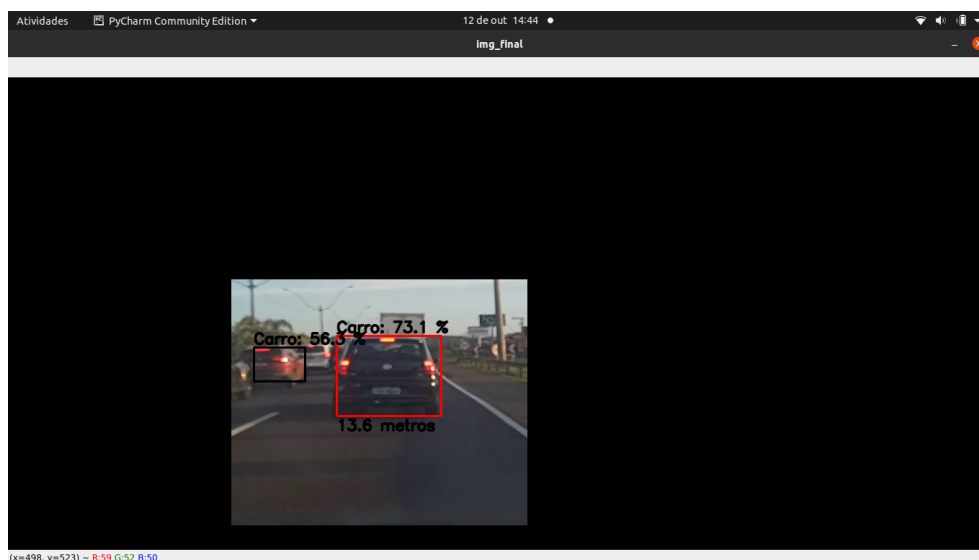
Distância real (metros)	Distância simulada (metros)	Erro (%)
3	3,2	1,07
5	4,9	2
8	7,6	5
10	9,4	6
12	10,4	13,33
14	12,4	11,43
16	14,6	8,75
18	16,1	10,56
20	17,1	14,5
	Erro médio	8,07

Fonte: Elaborado pelo Autor.

Estes valores representam um erro médio aproximado de 8 % o que considera-se um erro aceitável, tendo em vista a grande variabilidade das variáveis em questão e que são extraídos somente com o auxílio de imagens.

Além de fazer a estimativa de distância o sistema deve ser capaz de distinguir a pista que o veículo visível trafega e alterar as cores da caixa delimitadora dependendo desta posição, e, em caso de estar na mesma pista de rodagem alterar a coloração conforme a distância. Para veículos em faixas laterais a caixa delimitadora é representada pela cor preta como observado na Figura 15. Já veículos em frente ao condutor a distâncias menores que 22 metros a caixa delimitadora torna-se vermelha e a informação de distância é plotada na parte inferior da marcação, o que também pode ser observado na Figura 15.


Figura 15 Estimativa de distâncias e variação de cor da caixa delimitadora



Fonte: Elaborado pelo Autor.

Para veículos trafegando na mesma faixa a distâncias maiores que 22 metros a coloração da caixa delimitadora altera-se para laranja, observado na Figura 16.

Figura 16 Estimativa de distâncias para objetos à mais de 22 metros



Fonte: Elaborado pelo Autor.

Após a execução do teste de estimativa de distância e identificação de qual faixa de rodagem o objeto detectado está posicionado é possível partir para última etapa do trabalho que é agrupar todas as funções descritas até aqui em uma mesma imagem.

4.5 Resultado final

A validação final proposta neste trabalho de conclusão de curso é a apresentação das etapas de identificação de linhas de referência da rodovia, sugestão de rota, detecção de objetos e estimativa de distância em uma mesma imagem de saída, de acordo com a Figura 17.

Figura 17 Aplicação completa



Fonte: Elaborado pelo Autor.

Nesta figura é possível observar todos objetivos propostos atingidos considerando condições climáticas menos severas. Aplicando todos os blocos de funções o sistema apresentou uma exigência de processamento alta mesmo utilizando versão simplificada da rede neural de detecção de objetos foi possível atingir apenas 5 a 6 FPS de processamento gráfico. Ainda assim, apesar de não ideal, consegue-se verificar um vídeo fluído. Na Figura 18 foi disponibilizado um link para alguns vídeos demonstrativos das funcionalidades da aplicação.

Figura 18 QR Code - Vídeos demonstrativos



Fonte: Elaborado pelo Autor.

No próximo capítulo, Capítulo 5, é apresentada a conclusão sobre os resultados e abordagens metodológicas aplicadas.

5 CONCLUSÃO

Analisando os resultados obtidos pela aplicação conclui-se que a etapa de pré-processamento da imagem atingiu bons resultados, pois gera uma imagem limpa de ruídos em especial próximo as linhas de marcação horizontal da rodovia permitindo a visualização de linhas claras e bem definidas. Por consequência, os bons resultados no tratamento inicial da imagem permitem que a detecção de linhas de referência seja robusta e precisa em quase todas situações. Conforme destacado na Figura 11 para condições de chuva muito intensa a detecção de linhas foi prejudicada pelo acúmulo de água, sempre que o limpador de para-brisas desloca água sobre as linhas da pista a imagem fica distorcida e impede o reconhecimento adequado. Este processo de detecção de linhas é um dos mais importantes para o sistema pois é a partir destas informações que tem-se as referências da pista e consegue-se indicar as correções de direção e localizar se um veículo a frente está na mesma pista de rodagem. Portanto um bom desempenho neste quesito garante um melhor entendimento da situação do trânsito e melhor tomada de decisão. Visto que o sistema teve dificuldades de detecção apenas em caso bastante específico e de difícil visibilidade até mesmo para um condutor humano considera-se que o sistema atingiu os resultados esperados comprovando a eficácia do método aplicado.

A abordagem utilizada no processo de identificação de veículos também obteve êxito na grande maioria dos testes realizados. Como pode ser observado na Figura 14, assim como na etapa anterior, houve dificuldades de detecção em situações de chuva intensa justamente pelo motivo de distorções na imagem causados pelo excesso de água em frente a câmera. Considerando os demais testes aos quais a aplicação foi exposta, mesmo utilizando a versão *tiny* da rede neural YOLO atingiu-se bons índices de detecção veicular e desta forma pode ser considerada uma solução exequível para detecção de veículos em sistemas de visão computacional.

Por fim, o método de cálculo de distanciamento utilizado para sinalizar aproximação de veículos resultou em erro de aproximadamente 8% como indicado na Tabela 5. Tendo em vista que foi considerado uma largura real média padrão para qualquer tamanho de veículo identificado e as caixas delimitadoras geradas ao redor dos veículos detectados não mantém um tamanho idêntico em todos *frames* considera-se um percentual de erro relativamente baixo e aceitável para o sistema proposto. Entretanto vale ressaltar que a distância medida é estimada e desta forma deve-se considerar um fator de segurança durante alguma tomada de decisão.

De forma geral os algoritmos utilizados para resolução dos problemas propostos foram eficazes o que torna o sistema de mitigação de colisões viável. Como contribuição tecnológica pode-se citar o aumento de material de pesquisa na área de visão computacional em português e o próprio sistema desenvolvido que tomando os devidos cuidados pode ser utilizado para segurança de condutores em diversas situações. Como melhorias e trabalhos futuros para esta aplicação pode-se sugerir a aplicação da última versão da rede neural YOLO de detecção de objetos considerando também a necessidade de mais processamento. Realização de teste em outras situações de criticidade como grandes declives e curvas muito acentuadas para verificar o comportamento do sistema. Elaborar controle de movimentação de um veículo a partir da correção de direção, provendo um *feedback* de posição ao sistema. Fixar câmera diretamente no corpo do veículo visando diminuir o efeito de vibração nos vídeos e desta forma melhorando a qualidade das imagens. E medir a velocidade de tráfego do veículo possibilitando novas funcionalidades ao sistema.

REFERÊNCIAS

- ANDREAS HERRMANN WALTER BRENNER, R. S. **Autonomous Driving**. Howard House, UKEmerald, 2018.
- BARUA, B.; GOMES, C.; BAGHE, S.; SISODIA, J. A Self-Driving Car Implementation using Computer Vision for Detection and Navigation. In: INTERNATIONAL CONFERENCE ON INTELLIGENT COMPUTING AND CONTROL SYSTEMS (ICCS), 2019., 2019. **Anais...** 2019. p. 271–274.
- CHEN, C.-H.; CHEN, T.-Y.; HUANG, D.-Y.; FENG, K.-W. Front Vehicle Detection and Distance Estimation Using Single-Lens Video Camera. In: THIRD INTERNATIONAL CONFERENCE ON ROBOT, VISION AND SIGNAL PROCESSING (RVSP), 2015., 2015. **Anais...** 2015. p. 14–17.
- DANG, L.; TEWOLDE, G.; ZHANG, X.; KWON, J. Reduced resolution lane detection algorithm. In: IEEE AFRICON, 2017., 2017. **Anais...** 2017. p. 1459–1464.
- DENG, G.; WU, Y. Double Lane Line Edge Detection Method Based on Constraint Conditions Hough Transform. In: INTERNATIONAL SYMPOSIUM ON DISTRIBUTED COMPUTING AND APPLICATIONS FOR BUSINESS ENGINEERING AND SCIENCE (DCABES), 2018., 2018. **Anais...** 2018. p. 107–110.
- FARAG, W.; SALEH, Z. Road Lane-Lines Detection in Real-Time for Advanced Driving Assistance Systems. In: INTERNATIONAL CONFERENCE ON INNOVATION AND INTELLIGENCE FOR INFORMATICS, COMPUTING, AND TECHNOLOGIES (3ICT), 2018., 2018. **Anais...** 2018. p. 1–8.
- FENICHE, M.; MAZRI, T. Lane Detection and Tracking For Intelligent Vehicles: a survey. In: INTERNATIONAL CONFERENCE OF COMPUTER SCIENCE AND RENEWABLE ENERGIES (ICCSRE), 2019., 2019. **Anais...** 2019. p. 1–4.
- GONZALEZ, R. C.; WOODS, R. E. **Digital Image Processing**. 330 Hudson Street, New York, NY 10013Pearson, 2018.
- IBRAHIM, A. M.; HASSAN, R. M.; TAWFILES, A. E.; ISMAIL, T.; DARWEESH, M. S. Real-Time Collision Warning System Based on Computer Vision Using Mono Camera. In: NOVEL INTELLIGENT AND LEADING EMERGING SCIENCES CONFERENCE (NILES), 2020., 2020. **Anais...** 2020. p. 60–64.
- JAMES M. ANDERSON NIDHI KALRA, K. D. S. **Autonomous Vehicle Technology**. Santa Monica, CalifRAND Corporation, 2016.
- KIM, J.-G.; YOO, J.-H.; KOO, J.-C. Road and Lane Detection Using Stereo Camera. In: IEEE INTERNATIONAL CONFERENCE ON BIG DATA AND SMART COMPUTING (BIGCOMP), 2018., 2018. **Anais...** 2018. p. 649–652.

- KRISHNA, R. **Computer Vision: foundations and applications**. Stanford University, 2017.
- PETERS, J. F. **Foundations of Computer Vision**. Gewerbestrasse 11, 6330 Cham, SwitzerlandSpringer, 2017.
- RANFT, B.; STILLER, C. The Role of Machine Vision for Intelligent Vehicles. **IEEE Transactions on Intelligent Vehicles**, v. 1, n. 1, p. 8–19, 2016.
- SATZODA, R. K.; OHN-BAR, E.; LEE, J.; SONG, H.; TRIVEDI, M. M. On-road vehicle detection with monocular camera for embedded realization: robust algorithms and evaluations. In: INTERNATIONAL SOC DESIGN CONFERENCE (ISOCC), 2014., 2014. **Anais...** 2014. p. 150–151.
- SHIRKE, S.; RAJABHUSHANAM, C. A study of lane detection techniques and lane departure system. In: INTERNATIONAL CONFERENCE ON ALGORITHMS, METHODOLOGY, MODELS AND APPLICATIONS IN EMERGING TECHNOLOGIES (ICAMMAET), 2017., 2017. **Anais...** 2017. p. 1–4.
- SUN, Z. Vision Based Lane Detection for Self-Driving Car. In: IEEE INTERNATIONAL CONFERENCE ON ADVANCES IN ELECTRICAL ENGINEERING AND COMPUTER APPLICATIONS (AEECA), 2020., 2020. **Anais...** 2020. p. 635–638.
- TRANSPORTES, D. N. de Infraestrutura de. **Manual de sinalização rodoviária - 3.ed.** Rio de JaneiroIPR - 743, 2010.
- YANG, H.; WANG, Y.; GAO, L. A general line tracking algorithm based on computer vision. In: CHINESE CONTROL AND DECISION CONFERENCE (CCDC), 2016., 2016. **Anais...** 2016. p. 5365–5370.
- ZAARANE, A.; SLIMANI, I.; HAMDOUN, A.; ATOUF, I. Vehicle to vehicle distance measurement for self-driving systems. In: INTERNATIONAL CONFERENCE ON CONTROL, DECISION AND INFORMATION TECHNOLOGIES (CODIT), 2019., 2019. **Anais...** 2019. p. 1587–1591.
- ZHOU, C.; FAN, T. A Vehicle Recognition Method Based on Multi-Camera Information. In: CHINESE CONTROL CONFERENCE (CCC), 2019., 2019. **Anais...** 2019. p. 7835–7839.